



DETECCIÓN DE CRISIS EPILEPTICAS EN EL DOMINIO TEMPORAL A PARTIR DEL EEG MEDIANTE SVMs

Autor: Alejandro Boris Valiente

Tutor: Ángel Bravo Santos

Director: David Luengo García

11 Julio 2014

Índice



1. La Epilepsia
2. El Electroencefalograma
3. Detección de Crisis Epilépticas
4. Procesado de las Señales
5. Entrenamiento del Clasificador
6. Resultados
7. Conclusiones

1. La Epilepsia



“Afección crónica, de etiología diversa, caracterizada por crisis recurrentes debidas a una descarga excesiva de las neuronas cerebrales asociada eventualmente con diversas manifestaciones clínicas o paraclínicas”.

Características

- La epilepsia no constituye por sí misma una enfermedad
- En la clasificación internacional prevalece el criterio clínico: **Crisis Parciales, Generalizadas, No Clasificables**
- Los ataques se pueden controlar con medicación en un **70% de los casos**.
- En caso de que las epilepsias sean incontrolables con la medicación será necesario recurrir a la cirugía.

Relevancia


- La prevalencia mundial de la enfermedad oscila entre **4 y 10 de cada 1000 habitantes**.
- La tasa de incidencia mundial está entre **40 y 70 nuevos casos por cada 100.000 habitantes** al año.
- Hay 50 millones de afectados en todo el mundo, **360.000 en España**, en donde cada año aparecen 22.000 nuevos casos.
- **La epilepsia es tan común como la diabetes**. Sin embargo, sólo cuenta con una dieciseisava parte de los recursos.

2. El Electroencefalograma (2)



Uso del Electroencefalograma

- La **electroencefalografía** (EEG) es una exploración neurofisiológica que se basa en el registro de la actividad bioeléctrica cerebral.
- Desde el punto de vista de señal, es un **registro temporal en unidades de voltaje**, que permite monitorizar la actividad cerebral.
- Se suele medir mediante **montajes de electrodos** acompañados de otros elementos que ayudarán a interpretar la enfermedad neuronal del sujeto.
- El EEG está casi siempre “contaminado” por artefactos (internos y externos), lo que hace necesario el uso de técnicas de procesado.




Configuración Sistema Internacional 10-20

2. El Electroencefalograma (1)



Uso del Electroencefalograma en la Epilepsia

- **Ventajas en el uso del EEG** en investigaciones neurocientíficas:
 - Técnica no invasiva para el paciente en análisis.
 - La necesidad de permanecer inmóvil por parte del paciente es menos estricta.
 - Alta resolución temporal.
 - Mide la actividad eléctrica cerebral directamente.
- En la **epilepsia** es donde la electroencefalografía tiene un **mayor valor de diagnóstico**.
- La actividad epiléptica del EEG está constituida por cuatro etapas diferentes:
 - **Etapla Preictal**
 - **Etapla Ictal**
 - **Etapla Postictal**
 - **Etapla Interictal**



3. Detección de Crisis Epilépticas (1)



Técnicas de Caracterización de la Señal

- La complejidad de la Epilepsia hace necesario el **analizar distintos tipos de características intrínsecas** a las señales, cuya monitorización permita detectar anomalías cuando la crisis tiene lugar.
- Técnicas más representativas para la caracterización de señales.

Momentos Centrales de la Señal

$$\mu_k = E\{(X - E[X])^k\} = \int_{-\infty}^{\infty} (x - \bar{x})^k f(x) dx$$

- Para el presente proyecto se han revisado alguno de los momentos más característicos: **Varianza**, Skewness y Kurtosis

Técnicas Sofisticadas de Procesado

- El uso de técnicas más sofisticadas ayudan a **caracterizar los cambios dinámicos de los sistemas complejos**.
- Entre las técnicas estudiadas se encuentran: Densidad de Correlación, **Probabilidad Conjunta**, Dimensión de Correlación, exponente de Lyapunov, etc.

- Tras una revisión de metodologías de caracterización de señales, se han seleccionado dos para el posterior análisis del presente proyecto: **la Varianza y la probabilidad Conjunta**.


3. Detección de Crisis Epilépticas (2)



Característica 1: La Varianza

- Representa uno de los **estadísticos más simples** que puede ser usado para analizar las variaciones de una señal EEG.
- Es **uno de los atributos más usados** a la hora de caracterizar señales del EEG.
- La varianza provee un **punto de referencia base** con el que otros métodos deben de ser comparados.

$$\sigma^2 = \frac{\sum_{i=1}^N (x(i) - \bar{x})^2}{N}$$



3. Detección de Crisis Epilépticas (3)




Característica 2: La Probabilidad Conjunta


- Se observa una **clara diferencia** en la **representación de la función de densidad de probabilidad** de los periodos ictal e interictal.
- La probabilidad conjunta se suele utilizar para la detección de artefactos en una señal. Para nuestro estudio, **trataremos la crisis epiléptica como un evento extraño**.

$$J_e = -\log \left(\prod_{x \in A} p_{D_e}(x) \right) = -\sum_{x \in A} \log(p_{D_e}(x))$$

- p_{De}** : Función de densidad de probabilidad (PDF).
- A** : conjunto de instantes medidos para un canal determinado.



Representación Funciones de Densidad de Probabilidad



Uso de la probabilidad conjunta como característica

3. Detección de Crisis Epilépticas (4)



Elección del Clasificador como Detector


Existen dos formas distintas de abordar la clasificación de muestras:

- **Distinción dicotómica entre las dos clases**, y asignación de etiquetas de un tipo o de otro a una muestra de datos desconocida. (ejemplo: SVM – Support Vector Machine).
- Modelado de $P(y|x)$, para conocer **probabilidad de pertenencia a una determinada clase por parte de la muestra analizada** (ejemplo: los procesos gaussianos).

Máquina de vectores de Soporte (SVM)

- El clasificador utilizado en el estudio será una **SVM con un Kernel RBF**.

$$K(x, x_i) = \exp\left(-\frac{1}{2\sigma^2}\|x - x_i\|^2\right)$$







- La idea principal es construir un hiperplano como superficie de decisión para clasificar las muestras separando unas de otras.
- A la hora de entrenar una SVM es necesario elegir el valor de la **penalización del error** que se desea tener (a partir de ahora C).



3. Detección de Crisis Epilépticas (5)



Medición del rendimiento del Detector

		Realidad	
		SI	NO
Predicción	SI	 TP	 FP
	NO	 FN	 TN

Matriz de Confusión



$$① \text{ accuracy} = \frac{TP + TN}{TP + FN + TN + FP} = \frac{TP + TN}{N}$$

$$② \text{ sensitivity} = \frac{TP}{TP + FN}$$

$$③ \text{ specificity} = \frac{TN}{TN + FP}$$

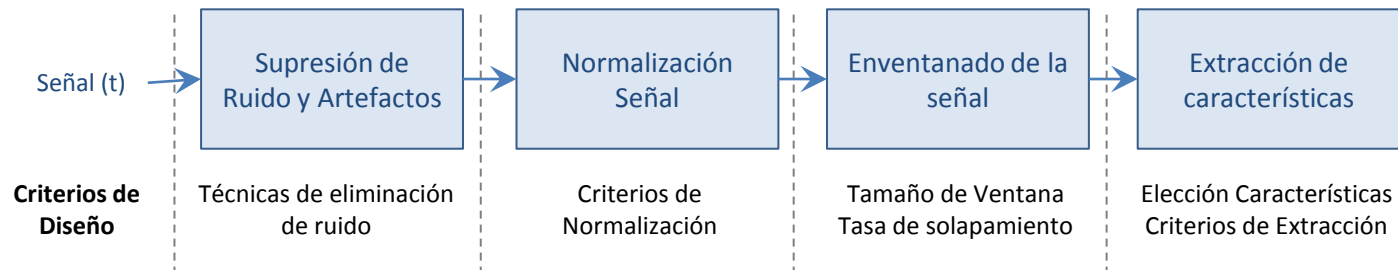
$$④ \text{ F1-score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} ; \text{precision} = \frac{TP}{TP + FP}$$

$$⑤ \text{ AUC} = \sum_{i=0} \left(\frac{(FP_{i+1} - FP_i)(TP_{i+1} + TP_i)}{2} \right)$$

4. Procesado de las Señales (1)



Diseño y Entrenamiento Clasificador




- **Supresión de Ruidos y Artefactos:** La señal es preprocesada para eliminar cualquier componente que pueda afectar a la extracción de características y posterior entrenamiento del clasificador.
- **Normalización Señal:** La señal es normalizada para que la señal resultante tenga media 0 y varianza 1.
- **Enventanado de la Señal:** La señal es troceada (enventanada) en grupos de muestras de un determinado tamaño para el posterior procesamiento de cada uno de estos subgrupos.
- **Extracción de características:** Cada uno de los subgrupos generados en la etapa anterior es procesado según el método de caracterización seleccionado. En nuestro caso, varianza y probabilidad conjunta.

4. Procesado de las Señales (2)



Supresión de Ruido y Artefactos y Normalización de la Señal



Supresión de Ruido y Artefactos

- Se ha trabajado con 2 tipos de procesado para la eliminación de ruido y artefactos:
 - **Filtro Paso Bajo a 20 Hz**
 - **ICA: “Independent Component Analysis”.**
- Se ha decidido trabajar con la **señal procesada con Filtro y con ICA.**

Normalización de la Señal



- La normalización cumple con una doble función:
 - Dotar del mismo peso a cada uno de los canales de entrada seleccionados
 - Permitir comparar resultados obtenidos en unos pacientes con otros
- Decisiones de diseño:
 - La señal se normalizará de cara a obtener una señal de media 0 y varianza 1.
 - Cada uno de los canales con crisis se normalizará de forma independiente.

4. Procesado de las Señales (3)





Enventanado de la Señal

- El **tamaño de la ventana** y la **tasa de solapamiento** permiten controlar el número de muestras a analizar y la cantidad de información por muestra.
- **Compromiso:** a mayor información por muestra menor número de muestras y viceversa.



Enventanados de la señal



Evolución de los indicadores de rendimiento con el tamaño de ventana

- El aumento en el tamaño de la ventana **mejora los resultados obtenidos hasta un tamaño de 1.600**, mientras que un tamaño mayor hace empeorar los resultados.
- A tenor de estos resultados, se ha decidido que **el tamaño de la ventana con el que se trabajará sea de 800 muestras**.
- Se elige además un solapamiento del 50% de las muestras.

4. Procesado de las Señales (4)




Extracción de Características

- Se procede a calcular el valor de las **características elegidas**: varianza y probabilidad conjunta.


$$\sigma^2 = \frac{\sum_{i=1}^N (x(i) - \bar{x})^2}{N}$$

$$J_e = - \sum_{x \in A} \log(p_{De}(x))$$

- Cada canal con crisis, y los atributos correspondientes al procesarlo, serán tratados de forma independiente.



Estimación Función Densidad de Probabilidad

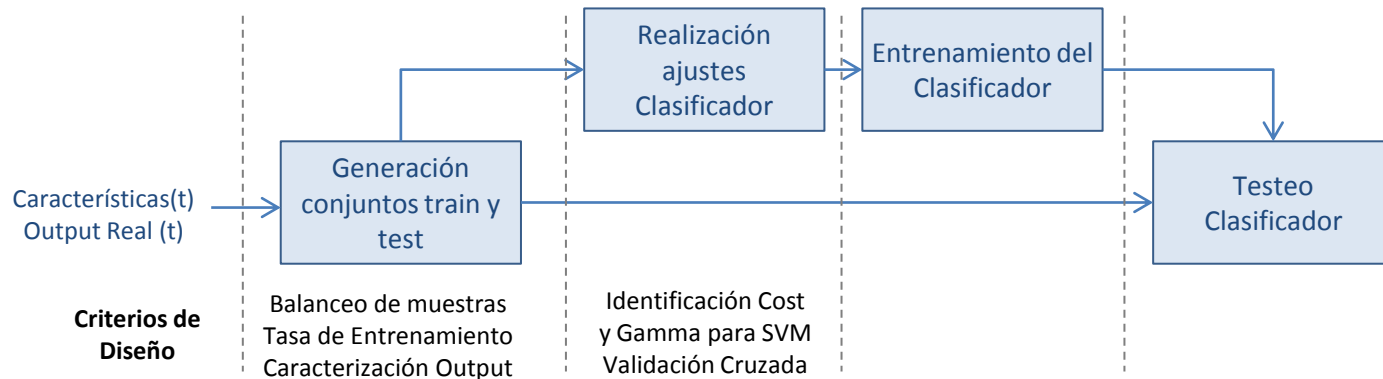


- Para cada muestra de la ventana se estima su valor p_{De} a partir del histograma obtenido.
- El clasificador alcanza un máximo en su rendimiento cuando el número de regiones utilizado es **10 regiones**.

5. Entrenamiento del Clasificador (1)



Diseño y Entrenamiento Clasificador




- **Generación conjuntos “train” y “test”:** Bloque encargado de dividir las señales que recibe a su entrada en dos conjuntos de señales: “train” y “test”.
- **Realización de ajustes del Clasificador:** Bloque encargado de ajustar los parámetros de la SVM que permitan maximizar los resultados obtenidos en la evaluación del clasificador.
- **Entrenamiento del Clasificador:** Se utilizará el conjunto de muestras seleccionados para el entrenamiento del primer bloque con el fin de que el clasificador ajuste sus criterios de decisión.
- **Testeo Clasificador:** El último bloque evaluará el rendimiento del clasificador entrenado y cuyos parámetros de diseño han sido previamente ajustados.

5. Entrenamiento del Clasificador (2)



Generación de Conjuntos “test” y “train”

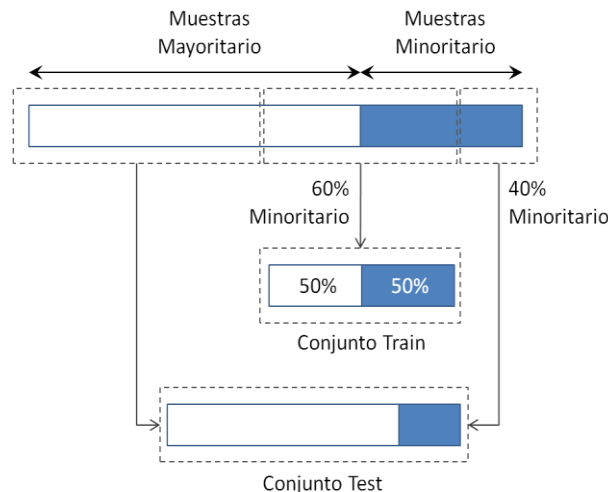


Balanceado de Muestras

- Los clasificadores se comportan mal con grupos de muestras desbalanceados.
- Alternativas Habituales:
 - Uso de costes/pesos.
 - Sobremuestreo del conjunto minoritario.
 - Inframuestreo del conjunto mayoritario.
- En este proyecto se ha utilizado la técnica del **inframuestreo**.

Tasa de Entrenamiento

- Se tomará siempre el **60% de las muestras del conjunto minoritario**, y se le añadirá el mismo número del conjunto mayoritario.




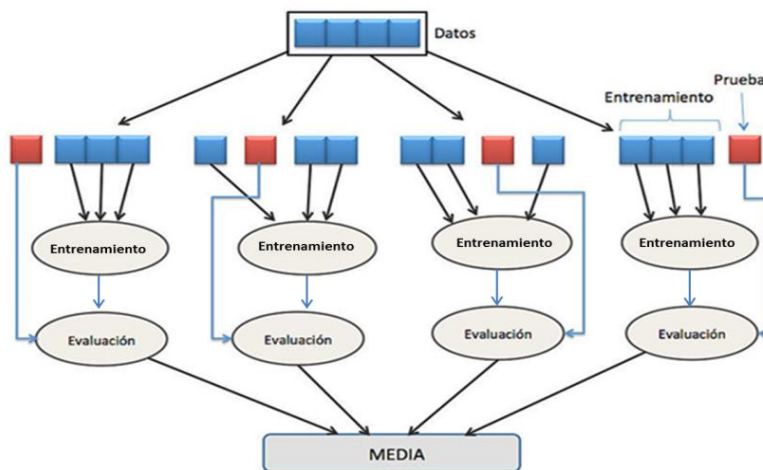

Clasificación Real de Muestras

- Ventana con crisis:** Se le asignará el valor 1.
- Ventana sin crisis:** Se le asignará el valor -1.
- Ventana descartada:** Se le asignará el valor 0 para poder ser luego descartadas.

5. Entrenamiento del Clasificador (3)



Realización de ajustes en el Clasificador




- La SVM con funciones RBF como “kernel”, necesita de la elección del valor de σ^2 y de la elección del valor de penalización del error (C).
- Para su estimación se utilizará el método de validación cruzada de k conjuntos.
- Este ejercicio se repetirá para cada pareja de valores de C y σ^2 , siguiendo la búsqueda en cuadrícula utilizada.

- Basado en los resultados obtenidos, el aumentar k no lleva implícita una mejora en el resultado obtenido en el clasificador.
- **Se ha optado por elegir $k=3$**

5. Entrenamiento del Clasificador (4)



Entrenamiento y Testeo del Clasificador



Entrenamiento del Clasificador

- El clasificador será entrenado con los conjuntos de entrenamiento x_{train} e y_{train} .
 - **x_{train}** representa la selección de muestras de los atributos de la señal obtenidos durante la caracterización
 - **y_{train}** representa la clasificación real de las muestras.
- A estos 2 conjuntos de muestras debe sumarse además la dupla de parámetros **Cost** y **Gamma** calculados en la Sección anterior.

Testeo del Clasificador

- Las muestras **x_{test}** serán clasificadas haciendo uso del clasificador obteniendo como resultado $f(x_{\text{test}})$.
- A partir de la clasificación realizada por el clasificador entrenado $f(x_{\text{test}})$ y de la **clasificación real y_{test}** , se calculará el valor de cada uno de los indicadores de rendimiento seleccionados.

6. Resultados (1)



Resumen de Condiciones de Pruebas Realizadas

○ Elección de Señales:

- Elección de los pacientes 3, 5 y 6
- Preprocesado con ICA y filtro paso bajo

○ Diseño del Caracterizador de Señales:

- Normalización (media 0 y varianza 1)
- Tamaño de ventana de 800 muestras con una tasa de solapamiento del 50%.
- Atributos: la varianza y la probabilidad conjunta (con histograma de 10 regiones).

○ Diseño del Clasificador:

- Para entrenar, 60% de las muestras del conjunto minoritario y el mismo número total del conjunto mayoritario.
- El clasificador será una SVM “Kernel” RBF.

Paciente	Núm Muestras	% Preictal	% Ictal	% Postictal
P1 – R1	36.573	52%	17%	31%
P1 – R2	15.106	28%	29%	43%
P1 – R3	8.112	50%	27%	22%
P1 – R4	11.633	37%	51%	12%
P1 – R5	18.970	46%	14%	40%
P2 – R1	58.774	29%	14%	56%
P2 – R2	32.939	30%	30%	40%
P3 – R1	79.511	26%	49%	25%
P3 – R2	85.030	21%	48%	31%
P4 – R1	64.999	31%	23%	46%
P4 – R2	62.542	13%	56%	31%
P5 – R1	66.992	29%	16%	55%
P5 – R2	81.137	18%	26%	56%
P6 – R1	67.303	56%	13%	31%
P6 – R2	130.542	36%	16%	48%
P6 – R3	58.600	56%	31%	13%

6. Resultados (2)



Resultados Finales – Rendimiento Clasificador

- Se evalúa el clasificador utilizando la Varianza y la Probabilidad Conjunta como atributos de la señal y el registro confeccionado a partir de los registros de los pacientes 3, 5 y 6.
- En la tabla se recoge los valores obtenidos tras la realización de 100 pruebas.

Indicadores	Media	Máximo	Mínimo	Desv. Típica
Exactitud	80,7%	85,5%	75,3%	2,2%
Sensibilidad	87,6%	98,7%	74,7%	5,4%
Especificidad	79,3%	87,2%	71,5%	3,5%
F1_score	60,9%	66,7%	55,2%	2,4%
AUC	88,8%	92,4%	84,0%	2,0%

- **Exactitud (Accuracy):** La media conseguida es del 80,7%. Es decir, 4 de cada 5 ventanas han sido bien clasificadas.
- **Sensibilidad (Sensitivity):** La media conseguida es del 87,76%. Casi 9 de cada 10 ventanas con crisis han sido detectadas.
- **Especificidad (Specificity):** La media conseguida es del 79,36%. Consiguen clasificar correctamente casi 8 de cada 10 ventanas sin crisis.
- **F1-Score:** La media obtenida es del 60,9%. Esto se debe a que la Precision es del 46,6%.
- **AUC (Área por debajo de la curva):** La media obtenida es 88,8% (valor considerado como bueno generalmente).

6. Resultados (3)



Resultados Finales – Comparativa

- Estos resultados se han comparado con los obtenidos en otros Proyectos Fin de Carrera que utilizaron el mismo grupo de señales pero distintas formas de caracterizarlas.

Indicadores	Clasificador Diseñado	PFC1	PFC2
Exactitud	80,7%	80,63%	86,3%
Sensibilidad	87,6%	64,5%	70,1%
Especificidad	79,3%	88,9%	92,3%
F1_score	60,9%	ND	ND
AUC	88,8%	ND	ND

- El clasificador diseñado en este proyecto **mejora en casi 20 puntos porcentuales los resultados de sensibilidad** alcanzado por los otros dos clasificadores.
- El clasificador diseñado es el **peor de los 3 clasificadores en lo referente al valor de Especificidad** (casi 10 puntos porcentuales inferior).
- Una posible causa de esta amplia diferencia en los resultados obtenidos (Sensibilidad y Especificidad) puede ser debido a **la falta de balanceado entre las muestras utilizadas para el entrenamiento del clasificador** en otros PFCs.

7. Conclusiones



DISEÑO

- No todos los registros de señales proporcionados sirven para el proyecto.
- Es recomendable el uso de herramientas que permitan la eliminación de artefactos.
- Los mejores resultados se obtienen con una ventana de un tamaño de 800 muestras.
- Una tasa de solapamiento alta ha facilitado la obtención de buenos resultados en el clasificador.
- La varianza, como atributo elegido para el procesamiento de la señal, es una variable estadística cuyo cálculo no reviste ninguna complicación.

RESULTADOS

- La Varianza y la Probabilidad Conjunta son atributos no complementarios.
- El correcto balanceado de las muestras es un *aspecto crítico* a la hora de obtener una correcta clasificación.
- Es posible la detección de muestras con crisis epilépticas a partir del uso de atributos como la Varianza o la Probabilidad Conjunta.